

(19) 日本国特許庁 (J P)

(12) 公開特許公報 (A)

(11) 特許出願公開番号

特開2000-163477

(P2000-163477A)

(43) 公開日 平成12年6月16日 (2000.6.16)

(51) IntCl ⁷	識別記号	F I	テーマコード(参考)
G 0 6 F 17/60		G 0 6 F 15/21	Z 5 B 0 4 9
13/00	3 5 4	13/00	3 5 4 D 5 B 0 8 9

審査請求 有 請求項の数 8 O L (全 13 頁)

(21) 出願番号 特願平10-337649

(22) 出願日 平成10年11月27日 (1998.11.27)

(71) 出願人 000004237

日本電気株式会社

東京都港区芝五丁目7番1号

(72) 発明者 中村 篤祥

東京都港区芝五丁目7番1号 日本電気株式会社内

(72) 発明者 安倍 直樹

東京都港区芝五丁目7番1号 日本電気株式会社内

(74) 代理人 100065385

弁理士 山下 穰平


最終頁に続く

(54) 【発明の名称】 表示広告選択方法

(57) 【要約】

【課題】 バナー広告を少ないデータから高いクリック率を達成する計算時間の少ない方法を提供することである。

【解決手段】 クリック実績の類似している属性のクラスタリングを行うクラスタ作成手段を有し、属性に対する広告の表示回数が少ないほど最低表示確率として大きな値を確保する最低表示確率確保手段を備え、広告のクリック率を類似している属性をもつ過去の広告から推定されるクリック率をクリック回数に加えて、それに対するGittins Indexで推定する目的関数係数決定手段を有し、解くべき制約付きの目的関数最大化問題を輸送問題の形式に変形し、輸送問題の解法を適用する目的関数最大化手段を有する学習手段 (図1の152) と、複数入力属性に対し1属性を無作為に選択し、その属性が属するクラスタを求めてからそのクラスタに対する各広告の表示確率に従って表示すべき広告を選択するという特徴を有する広告選択手段 (図1の151) とを有する。



【特許請求の範囲】

【請求項1】 WWW (World Wide Web) を介して閲覧されるページに表示されるバナー広告を、ページ閲覧要求時に送信されてくる情報、閲覧ページの情報、ユーザ情報等から得られる属性リストにより選択する表示広告選択方式であって、前記バナー広告の入力属性分布、前記バナー広告をクリックするクリック実績から各属性の入力確率と前記各属性に対する各広告のクリック率を推定して、前記バナー広告の目標表示回数等の条件を満たしながら全体のクリック率が最大になるように前記各属性に対して前記各バナー広告の表示確率を求める表示確率表作成手段を持つ学習手段と、前記表示確率に従って表示すべき前記バナー広告を選択する広告選択手段とを備えた表示広告選択方法において、

前記表示確率表作成手段によって求める制約付きの目的関数最大化問題を輸送問題の形式に変形し、前記輸送問題の解法を適用する目的関数最大化手段を有することを特徴とする表示広告選択方法。

【請求項2】 請求項1記載の表示広告選択方法において、前記学習手段に含まれる前記表示確率表作成手段の前処理として、前記クリック実績の類似している属性のクラスタリングを行うクラスタ表作成手段を備え、前記広告選択手段によって前記入力属性に対しその属性が属するクラスタを求めてからそのクラスタに対する前記各バナー広告の表示確率に従って表示すべき前記バナー広告を選択することを特徴とする表示広告選択方法。

【請求項3】 請求項2記載の表示広告選択方法において、前記クラスタ表作成手段は、前記属性のクラスタリングを、前記属性により条件づけられた条件付きクリック率を前記各属性に対する過去のクリック率実績から推定する問題として捉え、前記属性を束ねることにより推定パラメータを減らして推定精度を高める手段として、記述長最小原理を用いた欲張り戦略によって逐次的に最大もしくは準最大の総記述長減少をもたらす属性の結合を繰り返すことにより行うことを特徴とする表示広告選択方法。

【請求項4】 請求項2記載の表示広告選択方法において、前記クラスタ表作成手段は、前記属性のクラスタリングを、前記属性により条件づけられた条件付きクリック率を前記各属性に対する過去のクリック率実績から推定する問題として捉え、前記属性を束ねることにより推定パラメータを減らして推定精度を高める手段として、赤池情報量規準を用いた最大情報量減少対方式によって逐次的に最大もしくは準最大の情報量減少をもたらす属性の結合を繰り返すことにより行うことを特徴とする表示広告選択方法。

【請求項5】 前記属性に対する前記バナー広告の表示回数が少ないほど最低表示確率として大きな値を確保する最低表示確率確保手段を備えたことを特徴とする請求項1記載の表示広告選択方法。

【請求項6】 各々の前記属性 i 、前記バナー広告 j に対する前記クリック率の推定値 c を、表示回数とクリック回数から計算する表示広告選択方法において、前記バナー広告 j の前記属性 i に類似している属性をもつ過去のバナー広告 j' の前記属性 i に対する前記クリック率の推定値 μ を求め、前記属性 i の前記バナー広告 j に対する表示回数に1を加え、クリック回数に μ を加えた値から前記クリック率の推定値 c を計算することを特徴とする請求項1記載の表示広告選択方法。

10 【請求項7】 前記最大化する目的関数を構成する前記クリック率推定値の代わりに、Gittins Index または Laplace 推定により補正された「補正Gittins Index」を用いることを特徴とする請求項1記載の表示広告選択方法。

【請求項8】 複数属性の前記バナー広告に対するクリック入力に対し、1属性を無作為に選択し、その属性にたいする各バナー広告の表示確率に従って表示すべき前記バナー広告を選択することを特徴とする広告選択手段を備えていることを特徴とする請求項1記載の表示広告選択方法。

【発明の詳細な説明】

【0001】

【発明の属する技術分野】本発明は、情報フィルタリング技術に関し、特にWWW (World Wide Web) の各Webページに表示するのに適したバナー広告を選択する表示広告選択方法に関する。

【0002】

30 【従来の技術】ワールドワイドウェブ (World Wide Web) は、相互に関連付けたハイパーテキスト構造をもつインターネット上の情報発信システムおよびそのサーバシステムをいい、その実体は、インターネット上のハイパーテキストで書かれたページの集合体であり、単にウェブ (Web) と呼ぶ場合も多い。このウェブでは、当初はテキスト情報のみであったが、最近は画像や音声、動画といったマルチメディアデータを扱えるようになっている。ウェブでは、HTMLで記述されたウェブサイトのデータがサーバに蓄えられており、これらのデータのアクセスにhttpというプロトコルが使われ、世界中に散らばるウェブサイトを閲覧するため、ウェブブラウザというソフトウェアが使用されている。

【0003】このウェブのページに表示するバナー (Banner: 標識、マーク) 広告の選択は、ホームページ等のページ閲覧要求またはキーワード検索時に送信されてくる情報 (検索キーワード、ユーザドメイン名、ユーザID、日時等) や、閲覧ページの情報 (ページの内容、キーワード、カテゴリ等)、ユーザ情報 (過去の閲覧ページ、好みの分野等) を利用して行われている。

50 【0004】このような情報を利用したバナー広告の絞り込みの方法としては、規則を直接指定する方法、ユーザの過去の履歴から好みを学習して、好きと予想される

バナー広告を選択する方法がとられてきた(AdForce社のAdForce、AdKnowledge社のAdKnowledge、Double Click社のDART、Aptex社のSelect Cast for Ad Servers等)。

【0005】また、言葉や属性のクラスタリングの方法としては、様々な方法が存在する。例えば、記述長最小原理を用いた言葉のクラスタリングの方法としては、李、安倍による方法(特願平09-306966号「単語自動分類装置及び単語自動分類方法」に記載)がある。しかしながら、これまでバナー広告の配信において、過去のクリック実績データを基に、検索キーワードやページ属性をクラスタし、それを将来の広告の選択に活かす有効な方法は知られていなかった。

【0006】さらに、バナー広告を選択する際に、成功確率未知の選択肢が複数ある場合に、過去の試行において観測された成功数と失敗数に基づいて、次にとるべき最適な選択肢を特徴づけるGittins Indexなる概念が、ベイズ統計学の文脈で知られているが(J.C. Gittinsによる著書「Multi-armed bandit allocation indices」(John Wiley and Sons, 1988)に詳細に記載)、様々な制約条件のもとでクリック率が最大になるように、バナー広告を選択する方式において、この概念を活かす有効な方法は知られていなかった。

【0007】

【発明が解決しようとする課題】上述したように、従来の技術では、個々のページやユーザに適したバナー広告を表示することは出来るが、バナー広告の表示回数とクリック回数を監視しながら、バランスよく計算効率的にバナー広告を選択する能力に欠けていた。

【0008】また、検索キーワードや閲覧中のページ等の属性に連動して、表示広告を選択するにあたって、過去のクリック実績が類似する属性値をクラスタ化し、学習パラメータを減らすことにより学習の速度を高める機能に欠けていた。

【0009】さらに、属性を条件とした条件付きクリック率を学習するにあたって、クリック率の推定精度を高めるために様々な広告を選択する要請と、クリック推定値の高い広告を選択する要請との間のトレードオフを、最適に解決する機能に欠けていた。

【0010】本発明の目的は、バナー広告の表示回数とクリック回数のデータを使って、契約表示回数や契約クリック回数等の制約を満たしながら、全体のクリック率が大きくなるように、表示すべきバナー広告を選択する方法において、上記の諸問題を克服し、少ないデータから高いクリック率を達成する計算効率的な方法を提供することである。

【0011】

【課題を解決するための手段】前記目的を達成するため本発明は、WWW(World Wide Web)を介して閲覧されるページに表示されるバナー広告を、ページ閲覧要求時に送信されてくる情報、閲覧ページの情報、ユーザ情報

等から得られる属性リストにより選択する方式をとり、しかも入力属性分布、クリック実績から推定される各属性の入力確率と各属性に対する各広告のクリック率を使って、広告の目標表示回数等の条件を満たしながら全体のクリック率が最大になるように各属性に対して各広告の表示確率を求める表示確率表作成手段を特徴とする学習手段と、その確率に従って表示すべき広告を選択する広告選択手段を備えた方式において、上記の表示確率表作成手段において解く制約付きの目的関数最大化問題を輸送問題の形式に変形し、輸送問題の解法を適用する目的関数最大化手段を有することを特徴とする。

【0012】また、本発明は、上記の学習手段において表示確率表作成手段の前処理として、クリック実績の類似している属性のクラスタリングを行うクラスタ表作成手段を備え、上記の広告選択手段において入力属性に対しその属性が属するクラスタを求めてからそのクラスタに対する各広告の表示確率に従って表示すべき広告を選択することを特徴とする。

【0013】また、本発明は、第二の発明のクラスタ表作成手段において、属性のクラスタリングを、属性により条件づけられた条件付きクリック率を各属性に対する過去のクリック率実績から推定する問題として捉え、属性を束ねることにより推定パラメータを減らして推定精度を高める手段として、記述長最小原理を用いた欲張り戦略によって逐次的に最大もしくは準最大の総記述長減少をもたらす属性の結合を繰り返すことにより行うことを特徴とする。

【0014】また、上記表示広告選択方法のクラスタ表作成手段において、属性のクラスタリングを、属性により条件づけられた条件付きクリック率を各属性に対する過去のクリック率実績から推定する問題として捉え、属性を束ねることにより推定パラメータを減らして推定精度を高める手段として、赤池情報量規準を用いた欲張り戦略によって逐次的に最大もしくは準最大の情報量減少をもたらす属性の結合を繰り返すことにより行うことを特徴とする。

【0015】また、上記表示広告選択方法において、属性に対する広告の表示回数が少ないほど最低表示確率として大きな値を確保する最低表示確率確保手段を備えたことを特徴とする。

【0016】また、上記表示広告選択方法において、各々の属性 i 、広告 j に対するクリック率推定値 c を、表示回数とクリック回数から計算する方式において、広告 j の属性に類似している属性をもつ過去の広告 j' の属性 i に対するクリック率推定値 μ を求め、属性 i の広告 j に対する表示回数に1を加え、クリック回数に μ を加えた値から c を計算することを特徴とする。

【0017】また、上記表示広告選択方法において、最大化する目的関数を構成するクリック率推定値の代わりにGittins Index またはLaplace推定により補正された

「補正 Gittins Index」を用いることを特徴とする。

【0018】また、上記表示広告選択方法において、複数属性の入力に対し、1属性を無作為に選択し、その属性にたいする各広告の表示確率に従って表示すべき広告を選択することを特徴とする。

【0019】また、上記広告選択手段を備えている表示広告選択方法において、上記学習手段において、クリック実績の類似している属性のクラスタリングを行うクラスタ作成手段を有し、属性に対する広告の表示回数が少ないほど最低表示確率として大きな値を確保する最低表示確率確保手段を備え、広告のクリック率を類似している属性をもつ過去の広告から推定されるクリック率をクリック回数に加えて、それに対するGittins Indexで推定する目的関数係数決定手段を有し、解くべき制約付きの目的関数最大化問題を輸送問題の形式に変形し、輸送問題の解法を適用する目的関数最大化手段を有することを特徴とする。

【0020】また、上記広告選択手段において、複数入力属性に対し1属性を無作為に選択しその属性が属するクラスタを求めてからそのクラスタに対する各広告の表示確率に従って表示すべき広告を選択することを特徴とする。

【0021】

【発明の実施の形態】次に、本発明の実施形態について図面を参照して詳細に説明する。

【0022】〔第1の実施形態〕本発明の第1の実施形態について、図1を参照しつつ説明する。図1において、11はワールドワイドウェブ(WWW)としてのインターネット網に接続されているユーザであり、各ユーザは各種のホームページの閲覧やキーワード検索を行う。ホームページやキーワード検索サービスで情報を提供している情報提供会社13は、バナー広告を掲載することで広告収入を得ている。掲載広告の管理は煩雑であるため、自社または広告管理専門の会社の広告サーバで行なわれている。バナー広告をクリックすると広告提供者16のより詳細な広告情報にアクセスするようになっているため、バナー広告のクリック回数が多いほど広告提供者にとって広告の宣伝効果がある。

【0023】また、12はウェブ閲覧ソフトであり、ページ単位にテキスト、画像、音声のマルチメディアを表示できる。ホームページの閲覧やキーワード検索の要求を行うとそのサービスを提供している情報提供会社13から、要求されたコンテンツがウェブ閲覧ソフトに送信されてくる。そのページがバナー広告掲載ページである場合には、広告サーバ14に存在する広告呼出CGI

(Common Gateway Interface) プログラムのURL (Uniform Resource Locator) がコンテンツに埋め込まれており、それによりウェブ閲覧ソフトは広告サーバにバナー広告の選択とその画像データの送信を要求する。ここで、URLはインターネット上に存在する様々なデータ

のありかをそこまでのアクセス経路で記述するための書式であり、通常、プロトコル、サーバ名、ファイル名の順序で記述される。例えば、http://www.aabccc.co.jp/index.htmlのように記述される。広告サーバから送信されてきたバナー広告をクリックすると、広告サーバ14でクリック実績が記録された後、広告提供者16のもつ詳細な広告情報のホームページが表示される。

【0024】また、13は情報提供会社であり、インターネット上にコンテンツ121を提供しており、広告提供者16と契約して広告提供者のバナー広告をコンテンツ121のページに掲載するサービスも行っている。しかし、複数のバナー広告を複数のページに表示する契約を行うため、柔軟性を持たせるために、バナー広告をそのまま載せるのではなく、広告サーバに広告の選択と画像データの送信を行ってもらうために、その作業を行うCGIのプログラムのURLをコンテンツ121に埋め込んでウェブ閲覧ソフトに送信する。

【0025】また、14は情報提供会社13または広告管理専門の会社が備える広告サーバであり、広告サーバ14は、バナー広告を選択しその画像データを送信するバナー広告表示手段141と、クリックされた時にクリック実績を記録し広告提供者の詳細な広告ページを表示させる広告ページ表示手段143の他、広告選択を行うときに使われる表示確率関数を学習させるために入力属性分布145とクリック実績146と広告情報147を学習エンジンに提供する学習情報提供手段142と、広告の契約情報等を管理する広告管理手段144から構成される。

【0026】また、15は学習エンジンであり、学習エンジン15内には、広告選択手段151と、広告選択手段151が参照する予測表示確率関数を記憶する表示確率関数記憶部153と、表示確率関数記憶部153に記録する学習手段152と、学習手段152が参照・更新するデータ記憶部154とから構成されている。

【0027】図1を参照すると、本発明の実施形態による学習エンジン15は、バナー広告表示手段141から属性リストを入力として、表示確率関数記憶部153に格納されている予測表示確率関数を使って、適した広告IDを選択してバナー広告表示手段141に出力する広告選択手段151と、入力属性分布145、クリック実績146、広告情報147を入力として、データ記憶部154に格納されている過去のクリック実績146と広告属性を参照・更新し、表示確率関数記憶部153に格納されている表示確率関数を更新する学習手段152とを含んでいる。

【0028】つぎに、図2～図8を参照して、発明の実施形態の動作について詳細に説明する。

【0029】図2は、発明の実施形態における学習手段152の流れ図である。学習手段152の入力は、入力属性分布145、クリック実績146、広告情報147

の3つであり、広告サーバ14の学習情報提供手段142から提供される。入力属性分布145は、ある期間内に閲覧・検索された広告掲載ページの属性の出現頻度の情報であり、属性1と入力回数1、属性2と入力回数2、属性nと入力回数nとが対となって学習手段152に入力される。

【0030】また、クリック実績146は、各属性、各広告に対し、その属性をもつページにその広告を表示した表示回数と、その内クリックされたクリック回数の情報であり、それぞれが対となって学習手段152に入力される。広告情報147は、スケジューリング対象の広告の情報であり、各広告に対し、ある期間内の目標表示回数、レンタル属性（その属性のページにはある割合以上で広告を表示する契約）と、レンタル割合、抑制属性（その属性のページにはできる限り広告を表示しない契約）、及び広告属性（その広告を表すキーワード）を含んで学習手段152に入力される。

【0031】学習手段152は、クラスタ作成手段21と表示確率表作成手段22とからなる。クラスタ作成手段21は、入力情報を基に、属性のクラスタリングを行う。結果は表示確率関数記憶部153内にクラス表23として出力する。例えば、属性i(1)として属性1と属性4、属性6…とが同一クラスとして記録される。

$$d(x, j) \geq B(x, j) \quad (x=1, 2, \dots, s, j=1, \dots, m) \quad \dots (1)$$

を求める。但し、sはクラスタリング後の属性数、mは全公告数とする。

【0035】つぎに、目的関数係数決定手段222は、目的関数の係数 $c(x, j)$ を決定する。目的関数最大化手段223は、式(1)の制約式他、広告情報147に書かれている目標表示回数から計算される目標表示割合 $h(j)$ に関する制約式

【0036】

【数1】

$$\sum_{j=1}^m h(j) d(x, j) = h(j) \quad (j=1, \dots, m) \quad (2)$$

及び表示確率 $d(x, j)$ が、各属性 $i(x)$ に対し、全ての広告 j に対する和が1になるという制約式

【0037】

【数2】

$$\sum_{j=1}^m p(x, j) = h(j) \quad (j=1, \dots, m) \quad (5)$$

$$\sum_{j=1}^m p(x, j) = h(x) \quad (x=1, \dots, s) \quad (6)$$

$$p(x, j) \geq h(x) B(x, j) \quad (x=1, \dots, s, j=1, \dots, m) \quad (7)$$

を満たしながら目的関数

【0040】

【数5】

*【0032】また、表示確率表作成手段22は最低表示確率確保手段221、目的関数係数決定手段222、目的関数最大化手段223からなり、表示確率関数記憶部153内に表示確率表24を出力する。表示確率表24は、クラスタリング後の各属性 $i(x)$ に対する各広告 j の表示確率 $d(x, j)$ の表である。例えば、属性 $i(1)$ に対し、広告1の表示確率 $d(1, 1)$ は表示確率11、広告2の表示確率 $d(1, 2)$ は表示確率12…という表示確率表24が作成される。

10 【0033】ここで、入力属性分布145とクラス表23から求まるクラスタリング後の各属性 $i(x)$ の全体に対する入力割合を $k(x)$ とする。このとき、 $k(x) \cdot d(x, j)$ は属性 $i(x)$ のページが閲覧・検索され、しかも広告 j が表示される割合を表す。各属性 $i(x)$ 、各広告 j 毎に係数 $c(x, j)$ を考え、目的関数を、全ての属性 $i(x)$ 、全ての広告 j に関する $c(x, j) \cdot k(x) \cdot d(x, j)$ の和とする。表示確率表作成手段22では、この目的関数が $d(x, j)$ に関する制約式を満たす範囲内で最大になるように、表示確率 $d(x, j)$ を求める。

【0034】また、最低表示確率確保手段221では、広告情報147に書かれたレンタル属性、抑制属性、及び現時点までの表示回数から、表示確率 $d(x, j)$ に関する制約式

$$\sum_{j=1}^m d(x, j) = 1 \quad (x=1, \dots, s) \quad (3)$$

の3つの式を考え、制約式(1)(2)(3)を満たしながら、目的関数

【0038】

【数3】

$$\sum_{x=1}^s \sum_{j=1}^m c(x, j) h(x) d(x, j) \quad (4)$$

を最大化する線形計画問題を解く。ここで、

$$p(x, j) = k(x) \cdot d(x, j)$$

とおけば、この線形計画問題は制約式

【0039】

【数4】

※

$$\sum_{j=1}^m p(x, j) = h(j) \quad (j=1, \dots, m) \quad (5)$$

$$\sum_{j=1}^m p(x, j) = h(x) \quad (x=1, \dots, s) \quad (6)$$

$$p(x, j) \geq h(x) B(x, j) \quad (x=1, \dots, s, j=1, \dots, m) \quad (7)$$

★

$$\sum_{x=1}^s \sum_{j=1}^m c(x, j) p(x, j) \quad (8)$$

を最大化するヒッチコック型の輸送問題と呼ばれる特殊な型の線形計画問題に変換される。本発明では、式(8)に示す目的関数を有することを「輸送問題」と定義し、いわば線形計画問題に対する変形線形計画問題であるといえる。

【0041】また、本発明では、輸送問題に使われるシンプレックス法の特殊な解法(古林、「線形計画法入門」第8章輸送問題第8.5節シンプレックス法、産業図書、1980、pp.163-164)を利用する。ここで、輸送計画問題とは、例えば、何カ所かの工場で生産された製品(例えば、ビール)を、小売店に最も安上がりな方法で輸送する問題を解く最適化設計計画方法のひとつである。この場合、各工場での一製品の生産量と、小売店の販売量と、各工場から各小売店への輸送コストが与えられて、全体の輸送コストが最小になるように各工場から各小売店への輸送量を決めるという問題になる。この点に関し、本パナール広告選択問題では、属性クラス x の入力割合 $k(x)$ が工場 x における生産量、広告 j の目標表示割合 $h(j)$ が小売店 j の販売量、係数 $c(x, j)$ が工場から小売店 j への輸送コストに対応する。但し、本パナール広告選択問題では、工場 x から小売店 j への輸送量に対応する $d(x, j)$ を、総輸送コストに対応する値が最大になるように決める。

【0042】つぎに、図3を参照して、クラス表作成*

$$DD(P) = \sum_{i=1}^n \sum_{j=1}^m - \left(C(i, j) \log \frac{C(i, j)}{D(i, j)} + (D(i, j) - C(i, j)) \log \frac{D(i, j) - C(i, j)}{D(i, j)} \right) \quad (a)$$

また、情報量規準の他方の $MD(P)$ はモデルの複雑さを表しており、情報量規準として、何を用いるかによって定義が異なるが、ここでは、赤池情報量規準(AIC: Akaike Information Criterion)もしくは記述長最小原理(MDL: Minimum Description Length)を用いる。赤池情報量規準については、数理科学 No.153 1976年3月号掲載の赤池弘次による解説文「情報量規準AICとは何か」に、また記述長最小原理については、Automatica誌 Vo. 14 1978年、465頁-471頁掲載のJ. Rissanenによる論文「Modeling by shortest data description」に詳細に記載されている。

【0047】赤池情報量規準を用いた場合は、情報量規準によるモデルの難しさ $MD(P)$ は、自由パラメータ数となり、以下の式で与えられる。

【0048】

【数7】

$$MD_{AIC}(P) = \sum_{i=1}^n \sum_{j=1}^m 1 \quad (b)$$

この数式により、赤池情報量規準は定義される。

【0049】また、記述長最小原理(MDL: Minimum Description Length)を用いた場合は、 $MD(P)$ はモデル記述長となり、以下の式で与えられる。

【0050】

* 手段21の動作について詳細に説明する。

【0043】図3において、 P を属性集合の分割 $[P = \{c_1, c_2, \dots, c_s\}]$ とし、 P 中のクラス c_i に属する属性が入力された時、広告 j のバナーを表示すると確率 $c^P(i, j)$ でクリックされるという条件付き確率分布のモデルを考える。このとき、クラス c_i に属する属性が入力された時に、広告 j のバナーが表示された頻度を $D^P(i, j)$ 、その内クリックされた頻度を $C^P(i, j)$ とすると $c^P(i, j)$ の最尤推定量は $C^P(i, j)/D^P(i, j)$ である。ただし、ここで、 $D^P(i, j)$ 、 $C^P(i, j)$ は分割 P に依存する量なので、上付き添字 P を用いたが、以降分割 P は文脈から明らかなので省略する。

【0044】本発明のクラスタリング法は、情報量規準に基づいており、次の2つ値の和 $I(P) = DD(P) + MD(P)$ で分割 P を評価し、最も小さくなる分割を最良のものとする。

【0045】ここで、情報量規準の一方の $DD(P)$ はモデルの最大対数尤度(またはモデルによるデータ記述長とも呼ばれる)を表しており、以下の式によって定義される。

【0046】

【数6】

※【数8】

$$MD_{max}(P) = \sum_{i=1}^n \sum_{j=1}^m \frac{1}{2} \log D(i, j) \quad (c)$$

この数式により、記述長最小原理による情報量規準の他方を定義できる。

【0051】これは、それぞれのパラメータ $c(i, j)$ を

【0052】

【数9】

$$\log \sqrt{D(i, j)}$$

のビットで記述した時の記述長である。直観的には、推定値の分散が $O(1/D(i, j))$ と考えられるため、誤差を考えるとそれ以上の記述の必要はないことによる。なお、赤池情報量規準を用いた場合は $I(P)$ を情報量と呼び、記述長最小原理を用いた場合は $I(P)$ を記述長と呼ぶ。

【0053】さて、 $I(P)$ が最小となる分割 P を求めるにあたって、全ての分割 P を枚挙する方法をとると、計算量が膨大になってしまうので、本発明の方式は欲張りヒューリスティックに基づく計算量削減の最大情報量減少対方式である。即ち、この方式では、最初は1属性ずつ別々のクラスタに入るモデルを考え、最も情報量の

値が減るような2つのクラスタの結合を繰り返すという方法である。

【0054】図3に示すのは、この方式の流れ図である。クラスタ作成手段21は、初期化手段211、最大情報量減少対の発見手段212、停止条件試験手段213、最大情報量減少対の結合手段214、そして出力・終了手段215とからなる。

【0055】初期化手段211では、分割集合Pを全ての属性が一個属する集合の族として初期化される。また、全ての属性iと広告jに対して、 $D(\{i\}, j)$ と $C(\{i\}, j)$ がそれぞれ $D(i, j)$ と $C(i, j)$ として初期化される。

【0056】最大情報量減少対の発見手段212では、全ての属性クラスタの対p1、p2に対して、それらを結合した時にもたらされる情報量の減少量を計算し、その量を最大にする対を発見し、これをp1*、p2*として格納する。

【0057】停止条件試験手段213では、上記最大情報量減少対の発見手段212で発見された最大情報量減少対の情報量減少量が0以下か否かを計算し、もしそうであるならば、出力・終了手段215に進み、出力・終了手段215においてその時点の分割Pの値を出力して終了する。そうでないならば、最大情報量減少対の結合手段214に進み、Pの分割において、p1*、p2*を結合したものを新たな分割Pとして格納し、結合された新しいクラスタp1*U p2*に対して、クリック実績および表示回数実績を、それぞれのクラスタp1、p2のクリック実績および表示回数実績の和として更新し、最大情報量減少対の発見手段212に戻る。

【0058】なお、上記の最大情報量減少対の発見手段212において、全ての属性クラスタの対p1、p2に対して、それらを合併した時にもたらされる情報量の減少量を計算する代わりに、無作為に選ばれた複数の対p1、p2に対して、合併した時にもたらされる情報量の減少量を計算し、その量を最大にする対を発見し、p1*、p2*として格納することにより、計算効率性の向上を図ることも可能である。

$$B(a, j) = \min \left(\frac{1}{\sum_{j=1}^n B(a, j)}, \frac{M(j)}{\sum_{a=1}^m M(a) B(a, j)} \right) \quad (12)$$

により調節する。

【0064】また、図5～図7を参照して、目的関数決定手段222の動作について詳細に説明する。

【0065】図5は目的関数係数決定手段222の流れ図である。目的関数係数決定手段222では、クラスタリング後の各属性i(x)、各広告jに対し、最大化する目的関数の係数c(x, j)を決定する。先ず広告情報147により、属性i(x)が広告jの抑制属性であるかをチェックする(ステップ51)。抑制属性である場合(ステップ54)には $c(x, j) = -1$ とする。※50

*【0059】次に、図4～図7を参照して、表示確率表作成手段21の動作について詳細に説明する。

【0060】図4は表示確率表作成手段21の最低表示確率確保手段221の流れ図である。最低表示確率確保手段221は個別情報からの制約式作成のステップ41と、全体からみた調整ステップ42からなる。個別情報からの制約式作成のステップ41では、クラスタリング後の各属性i(x)、各広告jに対する制約式 $d(x, j) \geq B(x, j)$ を作成するために、 $B(x, j)$ の決定を行う。

【0061】先ず、属性x(i)が広告jの抑制属性の場合(ステップ411)には、 $B(x, j) = 0$ (9)

とする。属性i(x)が広告jの割合 $r(i(x), j)$ のレンタル属性の場合(ステップ412)には、 $B(x, j)$ は、

$$B(x, j) = r(i(x), j) \quad (10)$$

とする。属性i(x)が広告jの抑制属性でもレンタル属性でもない場合(ステップ413)には、表示回数 $D(x, j)$ が少ない場合の表示確率がある程度高くなるように、 $B(x, j)$ を、

【0062】

【数10】

$$B(a, j) = \frac{1}{2\pi\sqrt{D(a, j)+1}} \quad (11)$$

とする。全体からみた調整ステップ42では、ステップ41で作成された制約式による確保部分の合計が大きすぎないかチェックし調整する。ステップ421では、各属性i(x)に関し、全ての広告jに対する表示確率確保部分 $B(x, j)$ の合計が1を越えているか、また各広告jに関し、全ての属性i(x)によって、表示される確率 $k(x) \cdot B(x, j)$ の合計が、目標表示割合 $h(j)$ を越えているかをチェックし、越えている場合はステップ422にて式

【0063】

【数11】

※抑制属性でない場合は、広告情報147に書かれた広告属性から、データ記憶部154に格納されている過去の広告で最も似ているものを探し、そのクリック実績から広告jのクリック率 $\mu(x, j)$ を推定する(ステップ52)。

【0066】ここで、広告間の類似度に関する情報が欠如している場合、もしくは、それを利用しない場合には、 $\mu(x, j) = 1/2$ とすることも可能である。抑制属性でない場合のクリック率 $c(x, j)$ は、クリック実績146からわかる属性i(x)のページに広告j

が表示された回数 $D(x, j)$ に1を加えた値と、 $D(x, j)$ 回の内クリックされた回数 $C(x, j)$ をクリック率推定値 $\mu(x, j)$ を加えた値からクリック率を推定する推定関数 $Coeff$ によって求める(ステップ53)。ステップ53の推定関数 $Coeff$ には、様々なクリック率の推定法を用いることが可能であるが、通常は

【0067】

【数12】

$$Coeff(D(x, j) + 1, C(x, j) + \mu(x, j)) = \frac{C(x, j) + \mu(x, j)}{D(x, j) + 1}$$

とする。上記の推定関数 $Coeff$ の計算で、いわゆるGittins IndexまたはLaplace推定により補正された「補正Gittins Index」を用いて補正を行うことも可能であり、後に図7を用いて説明するように、本発明の提示広告選択方式ではこれを用いる。なお、Laplace推定量については、竹内啓編 統計学辞典(東洋経済新報社)の77頁〜78頁に「Laplaceの継起の法則」として詳細に記載されており、また、Gittins Indexについては、前述のJ. C. Gittinsによる著書「Multi-armed bandit allocation indices」(John Wiley and Sons, 1988)に詳細に記載されている。「補正Gittins Index」は本発明において導入された概念である。

【0068】つぎに、図6は、図5の広告属性からのクリック率 $\mu(x, j)$ の推定(ステップ52)の動作の流れ図である。まず、クリック実績146と広告情報147に出現する全ての属性と広告に関する情報を広告属性データベース64とクリック実績データベース65に反映する(ステップ61)。

【0069】次に、広告情報147内の各広告 j に対し、広告 j の広告属性集合 $v(j)$ と最も似ている広告属性集合 $v(y(j))$ をもつ広告 $y(j)$ を広告属性データベース64内で探す。広告属性データベース64には、過去の広告の広告属性集合が格納されている。広告属性集合 $v(j)$ と $v(j')$ の間の類似度 $Sim(v(j), v(j'))$ は、 $v(j)$ と $v(j')$ をベクトルとみた場合の成す角の余弦(\cos)で測り、次の式で計算される。

【0070】

【数13】

$$Sim(v(j), v(j')) = \frac{|v(j) \cdot v(j')|}{\sqrt{|v(j)| |v(j')|}} \quad (13)$$

但し、 $|v(j)|$ 、 $|v(j')|$ などは集合 $v(j)$ 、 $v(j')$ などの要素数を表し、 \cdot は内積演算を表す。最後に、クラスタ表23内の全ての属性 $i(x)$ 、広告情報147内の全ての広告 j に対し、ステップ62で求めた最も似ている広告 $y(j)$ のクリック実績をクリック実績データベース65で調べ、それからクリック率の推定値 $\mu(x, j)$ を求める(ステップ63)。

【0071】つぎに、クリック実績データベースには、過去の広告の各属性に対する表示回数と、クリック回数が格納されており、そのデータを使って属性 $i(x)$ のクラスタにまとめられた属性のページに広告 $y(j)$ が表示された回数 $D(x, y(j))$ と、その内クリックされた回数 $C(x, y(j))$ を求める。

【0072】図6に示すように、まず、 $D(x, y(j))$ が0か否かを調べる(ステップ631)。 $D(x, y(j))$ が0の場合には、クリック実績データベース65内の平均クリック率を $\mu(x, j)$ とする(ステップ632)。 $D(x, y(j))$ が0でない場合には、 $C(x, y(j))$ を $D(x, y(j))$ で割ったクリック割合を $\mu(x, j)$ とする(ステップ633)。

【0073】次に、図5のステップ53の関数 $Coeff$ のGittins IndexおよびLaplace推定により補正された「補正Gittins Index」を使った計算法について、図7を用いて詳細に説明する。

【0074】特定の属性値に対してどの広告を選択するかを考えた時に、Gittins Indexが最大のものを選択する方法は、遠い将来ほど割り引いて考えた場合の期待クリック回数を最大するという意味において、最適な方法である。なお、厳密には、ここでいう期待成功回数とは、 $t_i = 0, 1$ を i 回目の試行で成功するか(1)、失敗するか(0)、を表す確率変数として、

【0075】

【数14】

$$\sum_{t=1}^{\infty} g^{t-1} \cdot t_i$$

である。ただし、 g は未来をどの程度軽く見るかを定める定数($0 < g < 1$)である。Gittins Indexは観測されたクリックの割合が同じでも、提示数が少ないほど大きな値となるため、Gittins Index最大化戦略は、試行回数が少ないところを優先的に選択することによる知識の獲得と、推定クリック率が高いところを選択しやすいことによる知識の利用の両方を程よく行うのである。

【0076】ここでは、線形計画法による制約付き広告選択方式における目的関数の計算に、この考え方を導入することにより、制約充足と知識獲得と利用のトレードオフを同時に解決する方式を提供する。

【0077】今、 $(a+b)$ 回提示され、クリック回数が a 回、クリックされない回数が b 回の広告があったとする。このときのこの広告のGittins Index $I(a, b)$ は、他にもう一つ、クリック率既知 p の広告があったときに、どちらを選択しても(将来を割り引いた)期待成功回数が同じになるような p である。式で書くと次のようになる。成功回数が a 、失敗回数が b の広告と、成功確率が p の広告がある場合の期待成功回数を $R(a, b, p)$ とおくと、これは再帰的に

【0078】

【数15】

$$R(a, b, p) = \max \left(\frac{p}{1-g}, \frac{a}{a+b} (1 + gR(a+1, b, p)) + \frac{b}{a+b} gR(a, b+1, p) \right) \quad (14)$$

と書ける。Gittins Index $I(a, b)$ は
【0079】

* 【数16】

$$\frac{p}{1-g} = \frac{a}{a+b} (1 + gR(a+1, b, p)) + \frac{b}{a+b} gR(a, b+1, p) \quad (15)$$

を満たす値 p である。

【0080】実際の計算では、 p をある精度で変えながら式 (15) の左右の値が最も近くなる値を求めることになる。また、永遠に再帰させることもできないので、 $a+b$ がある値 Z の場合には

【0081】

【数17】

$$R(a, b, p) = \frac{a}{a+b} \cdot \frac{1}{1-g} \quad (16)$$

で計算し、それ以上再帰しないことにする。

【0082】図7に示すのは、上記のステップ53の推定関数 Coef の Gittins Index を使った計算手段の流れ図である。この計算手段は、初期化手段531、変数更新手段532、臨界条件判定手段533、再帰計算手段534、更新条件判定手段535、更新手段536、臨界ステップ537、終了条件判定手段538、出力／終了手段539からなる。

【0083】まず、初期化手段531において、誤差パラメータ D 、確率 p 、再帰終了パラメータ Z 、再帰パラメータ d 等を初期化する。次に、変数更新手段532において、これらのパラメータ p 、 d および成功数 a および、失敗数 b のパラメータを更新する。次に、臨界条件判定手段533において、臨界条件を計算し、これが満たされるならば、臨界ステップ537に進み、そうでないならば再帰計算手段534に進む。臨界ステップ537では、 $R(a, b, p)$ と $I(a, b)$ の値を再帰することなく、近似式により計算する。ここで、通常の Gittins Index の計算では、

【0084】

【数18】

$$R(a, b, p) = \frac{a}{(a+b)(1-g)}$$

$$I(a, b) = \frac{a}{a+b}$$

と計算する。図7では、Laplace推定による補正Gittins Indexを計算する場合の計算式を書いた。

【0085】即ち、図7によれば、臨界ステップ537の数式中、成功率は $a/(a+b)$ で表せるが、Laplace推定により成功率は $(a+0.5)/(a+b+1)$ と表せ、これを期待成功回数 $R(a, b, p)$ と Gittins Index $I(a, b)$ に適用したことが特徴となる。また、再起計算手段543のRHSの数式内の失敗率である $(b+0.5)/(a+b+1)$ も、Laplace推定で ※50

※表したものである。従って、補正Gittins Indexは、臨界ステップ537及び再起計算手段543によって計算された計算手段で表されたものであるといえる。

【0086】この場合、通常のGittins Indexでは、成功数が0の選択肢の価値は0になってしまうので、最初の何回かの試行で運悪く成功がない選択肢が後に選ばれなくなるという問題があったが、Laplace推定による補正を加えることにより、この問題が解決される。

【0087】さらに、図5の目的関数決定手段222の動作の説明において記述されたように、類似広告を用いてこれを補正することも可能であり、この場合には、臨界ステップ537の計算式は

【0088】

【数19】

$$R(a, b, p) = \frac{a + \mu(a, j)}{(a+b+1)(1-g)}$$

$$I(a, b) = \frac{a + \mu(a, j)}{a+b+1}$$

となる。臨界条件判定手段533または臨界ステップ537の次は、再帰計算手段534に進む。再帰計算手段534では、LHSとRHSを計算式に従って計算し、 $\max(LHS, RHS)$ の値を $R(a, b, p)$ に格納する。ここで、RHSの計算に用いられる $R(a+1, b, p)$ および $R(a, b+1, p)$ は、再帰パラメータの更新順序により、既に計算されていることが保証されている。

【0089】次に、更新条件判定手段535によって、再帰計算手段534で計算されたLHSとRHSの値の差が、 $D(a, b)$ より小さいかが試験され、その場合には更新手段536において、 $I(a, b)$ および $D(a, b)$ の値が更新される。

【0090】次に、停止条件判定手段538において、 $d=0$ か否かが計算され、その場合は I の値を出力し、手続きを出力／終了手段539で終了し、そうでない場合は、変数更新手段532に戻る。

【0091】図8は広告選択手段151の流れ図である。広告選択手段151は次のような動作により、入力された属性リスト84に適した1つの広告ID85を選択する。

【0092】まず、属性リスト内から1つの属性 i を無作為抽出する(ステップ81)。次に、表示確率関数記憶部153に格納されているクラスタ表23を使って、

属性 i が属するクラスタの代表属性 i' を求める（ステップ82）。最後に、表示確率関数記憶部153に格納されている表示確率表24を使って、属性 i' の各広告の表示確率に基づき、広告IDをランダムに選択する（ステップ83）。

【0093】

【発明の効果】以上説明したように、本発明の表示広告選択方式によれば、各属性の各バナー広告に対する少ない表示回数から得られるクリック実績データから、全体の推定クリック率が最も高くなるような入力属性に対する各広告の表示確率を高速に計算することができ、その表示確率によって広告を選択することにより、全体のクリック回数が実際に増すことが期待できる。

【図面の簡単な説明】

【図1】本発明の実施形態の構成を示すブロック図である。

【図2】本発明の実施形態の学習手段を示す流れ図である。

【図3】本発明の実施形態のクラスタ表更新手段を示す流れ図である。

【図4】本発明の実施形態の最低表示確率確保手段を示す流れ図である。

【図5】本発明の実施形態の目的関数係数決定手段を示す流れ図である。

【図6】本発明の実施形態のステップ52の詳細を示す流れ図である。

【図7】本発明の実施形態のステップ53の詳細を示す

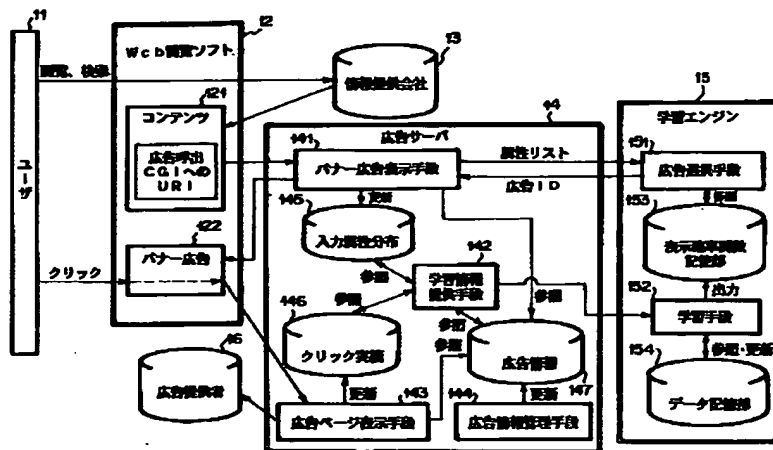
流れ図である。

【図8】本発明の実施形態の広告選択手段を示す流れ図である。

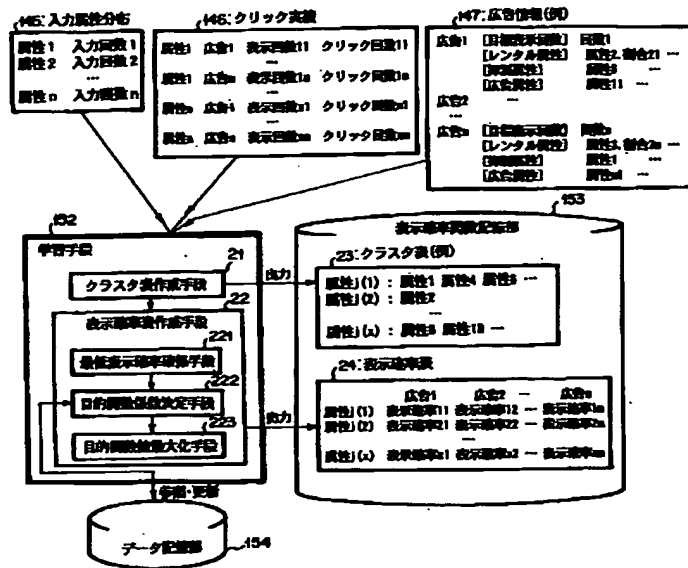
【符号の説明】

- 11 ユーザ
- 12 ウェブ閲覧ソフト
- 13 情報提供会社
- 14 広告サーバ
- 15 学習エンジン
- 21 クラスタ表示作成手段
- 22 表示確率表作成手段
- 23 クラスタ表
- 24 表示確率表
- 41 制約式作成のステップ
- 42 調整ステップ
- 141 バナー広告表示手段
- 142 学習情報提供手段
- 143 広告ページ表示手段
- 144 広告情報管理手段
- 145 入力属性分布記録手段
- 146 クリック実績記録手段
- 147 広告情報記録手段
- 151 広告選択手段
- 152 学習手段
- 153 表示確率関数記憶部
- 154 データ記憶部

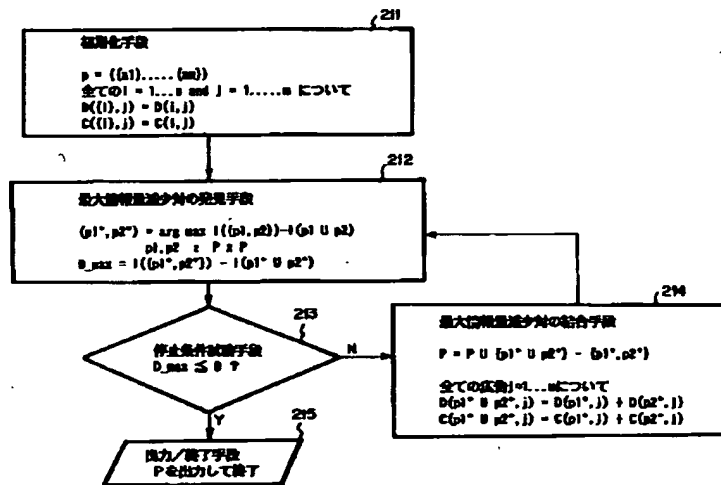
【図1】



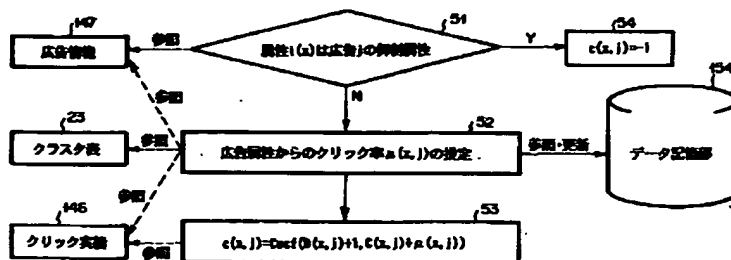
【図2】



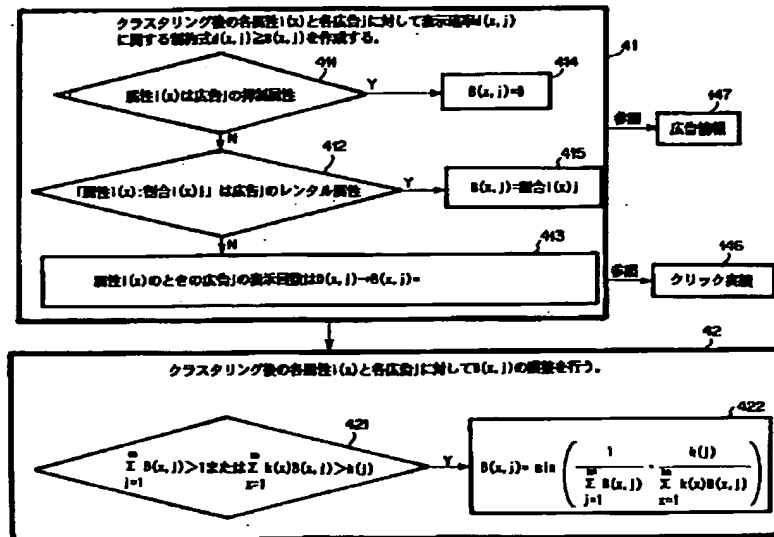
【図3】



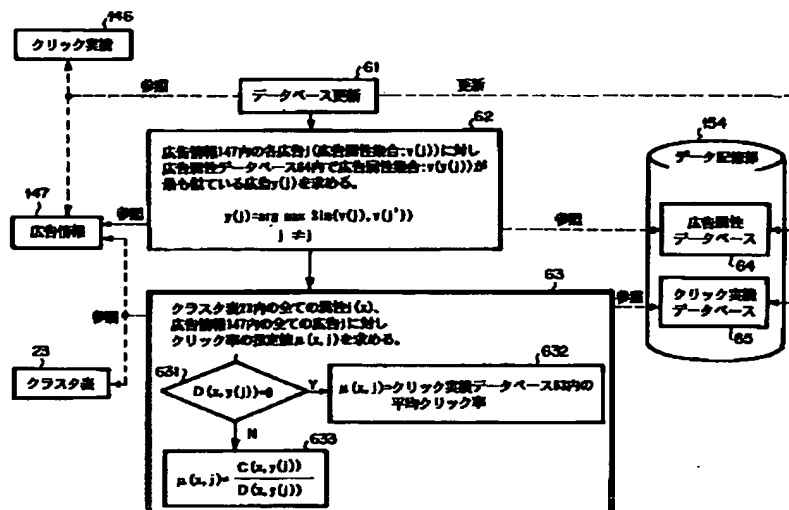
【図5】



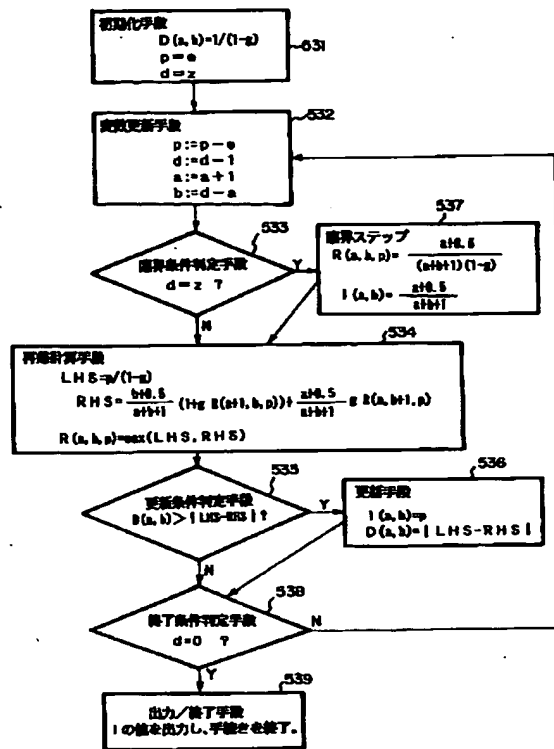
【図4】



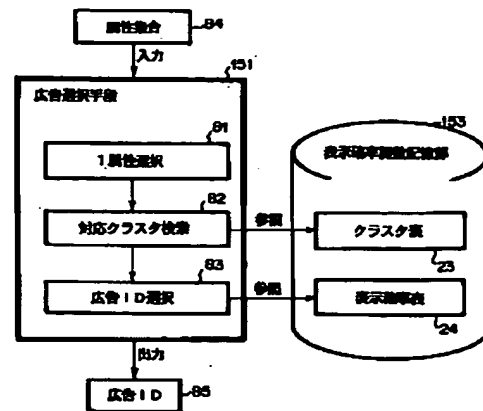
【図6】



【図7】



【図8】



フロントページの続き

Fターム(参考) 5B049 BB49 DD01 EE02 EE03 GG02
 GG09
 5B089 GA21 HA10 JA22 JA40 JB02
 KA05 KC53 LB20